

# Модели и методы интеллектуального анализа данных

Рудаков Константин Владимирович  
Воронцов Константин Вячеславович

Международная научная конференция по информатике  
и прикладной математике, посвященная 60-летию  
Вычислительного центра им. А.А. Дородницына РАН

Москва, ВЦ РАН • 9–10 декабря 2015

- 1 Восстановление зависимостей по эмпирическим данным**
  - Задачи машинного обучения
  - Переобучение линейных моделей
  - Регуляризация в линейных моделях
- 2 Регуляризация в задачах машинного обучения**
  - Регуляризации для отбора признаков
  - Нестационарная линейная регрессия
  - Автоматическое порождение и выбор моделей
- 3 Композиции регуляризаторов и матричные разложения**
  - Задачи матричного разложения
  - Вероятностное тематическое моделирование
  - Проект BigARTM. Эксперименты

## Задача статистического (машинного) обучения с учителем

$\mathbb{X}$  — объекты;  $\mathbb{Y}$  — ответы (классы, прогнозы);

$y^*: \mathbb{X} \rightarrow \mathbb{Y}$  — неизвестная зависимость.

**Дано:**  $X^\ell$  — обучающая выборка объектов  $x_i = (x_i^1, \dots, x_i^n)$   
с известными ответами  $y_i = y^*(x)$ ,  $i = 1, \dots, \ell$ :

$$\begin{pmatrix} x_1^1 & \dots & x_1^n \\ \dots & \dots & \dots \\ x_\ell^1 & \dots & x_\ell^n \end{pmatrix} \xrightarrow{y^*} \begin{pmatrix} y_1 \\ \dots \\ y_\ell \end{pmatrix}$$

**Найти:** алгоритм  $a: \mathbb{X} \rightarrow \mathbb{Y}$ , способный давать правильные  
ответы на *тестовых объектах*  $\tilde{x}_i = (\tilde{x}_i^1, \dots, \tilde{x}_i^n)$ ,  $i = 1, \dots, k$ :

$$\begin{pmatrix} \tilde{x}_1^1 & \dots & \tilde{x}_1^n \\ \dots & \dots & \dots \\ \tilde{x}_k^1 & \dots & \tilde{x}_k^n \end{pmatrix} \xrightarrow{a?} \begin{pmatrix} a(\tilde{x}_1) \\ \dots \\ a(\tilde{x}_k) \end{pmatrix}$$

## Примеры прикладных задач обучения по прецедентам

- Распознавание, классификация, принятие решений ( $|\mathbb{Y}| < \infty$ ):
  - $x$  — ЭМК пациента;  $y$  — диагноз, лечение;
  - $x$  — заёмщик;  $y$  — вероятность дефолта;
  - $x$  — абонент;  $y$  — вероятность ухода к другому оператору;
  - $x$  — текстовое сообщение;  $y$  — спам / не спам;
  - $x$  — документ;  $y$  — категория в рубрикаторе;
  - $x$  — фрагмент белка;  $y$  — тип вторичной структуры;
  - $x$  — фрагмент ДНК;  $y$  — функция: промотор / ген;
  - $x$  — фотопортрет;  $y$  — идентификатор личности;
- Регрессия и прогнозирование ( $\mathbb{Y} = \mathbb{R}$  или  $\mathbb{R}^m$ ):
  - $x$  —  $\langle$ товар, магазин, дата $\rangle$ ;  $y$  — объём продаж;
  - $x$  —  $\langle$ клиент, товар $\rangle$ ;  $y$  — рейтинг товара;
  - $x$  — параметры технолог. процесса;  $y$  — свойство продукции;
  - $x$  — структура хим. соединения;  $y$  — его свойство;
  - $x$  — характеристики недвижимости;  $y$  — цена;

## Задачи, некорректно поставленные по Адамару

Корректно поставленная задача:

- решение существует,
- решение единственно,
- решение устойчиво (непрерывно зависит от данных в некоторой разумной топологии).



Жак Саломон Адамар  
(1865–1963),  
почётный член АН СССР (1929)

Задачи восстановления зависимостей по эмпирическим данным — всегда некорректно поставленные.

---

*Hadamard J.* Sur les problèmes aux dérivées partielles et leur signification physique. 1902.

*Тихонов А. Н., Арсенин В. Я.* Методы решения некорректных задач. 1974.

## Обучение регрессии — это оптимизация

Задача регрессии,  $a: \mathbb{X} \rightarrow \mathbb{R}$

- 1 Выбираем модель регрессии, например, линейную:

$$a(x, w) = \langle x, w \rangle = \sum_{j=1}^n x^j w_j, \quad x, w \in \mathbb{R}^n$$

- 2 Выбираем функцию потерь, например, квадратичную:

$$\mathcal{L}(a, y) = (a - y)^2$$

- 3 Минимизируем эмпирический риск — это МНК:

$$Q(a, X^\ell) = \frac{1}{\ell} \sum_{i=1}^{\ell} (a(x_i, w) - y_i)^2 \rightarrow \min_w$$

- 4 Проверяем прогностическую (обобщающую) способность:

$$Q(a, X^k) = \frac{1}{k} \sum_{i=1}^k (a(\tilde{x}_i, w) - \tilde{y}_i)^2$$

## Обучение классификации — это тоже оптимизация

**Задача классификации** с двумя классами,  $a: \mathbb{X} \rightarrow \{-1, +1\}$

- 1 Выбираем **модель классификации**, например, линейную:

$$a(x, w) = \text{sign}\langle x, w \rangle$$

- 2 Выбираем функцию потерь, например, **число ошибок**:

$$\mathcal{L}(a, y) = [ay < 0]$$

- 3 Минимизируем эмпирический риск:

$$Q(a, X^\ell) = \frac{1}{\ell} \sum_{i=1}^{\ell} [a(x_i, w)y_i < 0] \rightarrow \min_w$$

- 4 Проверяем прогностическую (обобщающую) способность:

$$Q(a, X^k) = \frac{1}{k} \sum_{i=1}^k [a(\tilde{x}_i, w)\tilde{y}_i < 0]$$

## Минимизация аппроксимированного эмпирического риска

Задача классификации с двумя классами,  $a: \mathbb{X} \rightarrow \{-1, +1\}$

- 1 Выбираем модель классификации, например, линейную:

$$a(x, w) = \text{sign}\langle x, w \rangle$$

- 2 Аппроксимируем пороговую функцию потерь непрерывной:

$$[M_i < 0] \leq \mathcal{L}(M_i), \quad M_i = \langle x_i, w \rangle y_i \text{ — отступ (margin)}$$

- 3 Минимизируем **аппроксимированный** эмпирический риск:


$$\tilde{Q}(a, X^\ell) = \frac{1}{\ell} \sum_{i=1}^{\ell} \mathcal{L}(\langle x_i, w \rangle y_i) \rightarrow \min_w$$

- 4 Проверяем прогностическую (обобщающую) способность:

$$Q(a, X^k) = \frac{1}{k} \sum_{i=1}^k [a(\tilde{x}_i, w) \tilde{y}_i < 0]$$

## Непрерывные аппроксимации пороговой функции потерь

Часто используемые непрерывные функции потерь  $\mathcal{L}(M)$ :



$$V(M) = (1 - M)_+$$

$$H(M) = (-M)_+$$

$$L(M) = \log_2(1 + e^{-M})$$

$$Q(M) = (1 - M)^2$$

$$S(M) = 2(1 + e^M)^{-1}$$

$$E(M) = e^{-M}$$

$$[M < 0]$$

— кусочно-линейная (SVM);

— кусочно-линейная (Hebb's rule);

— логарифмическая (LR);

— квадратичная (FLD);

— сигмоидная (ANN);


— экспоненциальная (AdaBoost);

— пороговая функция потерь.

## Проблема переобучения в прикладных задачах классификации

Задача предсказания отдалённого результата хирургического лечения атеросклероза. Точки — различные алгоритмы.

*Частота ошибок на контроле, %*



*Частота ошибок на обучении, %*

## Причины переобучения линейных моделей

- 1 слишком мало объектов; слишком много признаков;
- 2 линейная зависимость (мультиколлинеарность) признаков:

$$\exists v \in \mathbb{R}^n: \quad \forall x \quad \langle x, v \rangle \approx 0;$$

тогда

$$\forall \gamma \in \mathbb{R} \quad a(x, w) = \text{sign} \langle x, w \rangle \approx \text{sign} \langle x, w + \gamma v \rangle$$

Последствия:

- слишком большие веса  $|w_j|$ ;
- неустойчивость классификаций  $a(x, w)$ ;
- $Q(X^\ell) \ll Q(X^k)$ ;

Суть проблемы — задача некорректно поставлена.

Решение проблемы — регуляризация, ограничивающая  $w$ .

## Часто используемые регуляризаторы

- 1  $L_2$ -регуляризация (SVM, RLR, гребневая регрессия)

$$\tilde{Q}(a, X^\ell) = \frac{1}{\ell} \sum_{i=1}^{\ell} \mathcal{L}(\langle x_i, w \rangle y_i) + \mu \sum_{j=1}^n w_j^2 \rightarrow \min_w$$

- 2  $L_1$ -регуляризация (LASSO)

$$\tilde{Q}(a, X^\ell) = \frac{1}{\ell} \sum_{i=1}^{\ell} \mathcal{L}(\langle x_i, w \rangle y_i) + \mu \sum_{j=1}^n |w_j| \rightarrow \min_w$$

- 3  $L_0$ -регуляризация (AIC, BIC, VCdim, OBD)

$$\tilde{Q}(a, X^\ell) = \frac{1}{\ell} \sum_{i=1}^{\ell} \mathcal{L}(\langle x_i, w \rangle y_i) + \mu \sum_{j=1}^n [w_j \neq 0] \rightarrow \min_w$$

## Наиболее известные линейные методы классификации

$a(x, w) = \text{sign}(\langle x, w \rangle - w_0)$  — линейный классификатор

$M_i(w, w_0) = y_i(\langle x_i, w \rangle - w_0)$  — отступ (margin) объекта  $x_i$

- 1 Метод опорных векторов (SVM, Support Vector Machine):

$$\sum_{i=1}^{\ell} (1 - M_i(w, w_0))_+ + \frac{1}{2C} \|w\|^2 \rightarrow \min_{w, w_0} .$$

- 2 Логистическая регрессия (LR, Logistic Regression):

$$\sum_{i=1}^{\ell} \ln(1 + \exp(-M_i(w, w_0))) \rightarrow \min_{w, w_0} .$$

- 3 Регуляризованная логистическая регрессия (RLR):

$$\sum_{i=1}^{\ell} \ln(1 + \exp(-M_i(w, w_0))) + \frac{\mu}{2} \|w\|^2 \rightarrow \min_{w, w_0} .$$

## Негладкий регуляризатор приводит к отбору признаков

LASSO — least absolute shrinkage and selection operator

$$\sum_{i=1}^{\ell} \text{Loss}_i(w) + \mu \sum_{j=1}^n |w_j| \rightarrow \min_w.$$

Замена переменных:  $u_j = \frac{1}{2}(|w_j| + w_j)$ ,  $v_j = \frac{1}{2}(|w_j| - w_j)$ .  
Тогда  $w_j = u_j - v_j$  и  $|w_j| = u_j + v_j$ ;

$$\begin{cases} \sum_{i=1}^{\ell} \text{Loss}_i(u - v) + \mu \sum_{j=1}^n (u_j + v_j) \rightarrow \min_{u,v} \\ u_j \geq 0, \quad v_j \geq 0, \quad j = 1, \dots, n; \end{cases}$$

чем больше  $\mu$ , тем больше ограничений-неравенств активны,  
но если  $u_j = v_j = 0$ , то  $w_j = 0$  и  **$j$ -й признак не учитывается.**

## 1-norm SVM (LASSO SVM)

LASSO — least absolute shrinkage and selection operator

$$\sum_{i=1}^{\ell} (1 - M_i(w, w_0))_+ + \mu \sum_{j=1}^n |w_j| \rightarrow \min_{w, w_0} .$$

- ⊕ Отбор признаков с параметром *селективности*  $\mu$ : чем больше  $\mu$ , тем меньше признаков останется
- ⊖ LASSO начинает отбрасывать значимые признаки, когда ещё не все шумовые отброшены
- ⊖ Нет *эффекта группировки* (grouping effect): значимые зависимые признаки должны отбираться вместе и иметь примерно равные веса  $w_j$

---

Bradley P., Mangasarian O. Feature selection via concave minimization and support vector machines // ICML 1998.

## Doubly Regularized SVM (Elastic Net SVM)

$$C \sum_{i=1}^{\ell} (1 - M_i(w, w_0))_+ + \mu \sum_{j=1}^n |w_j| + \frac{1}{2} \sum_{j=1}^n w_j^2 \rightarrow \min_{w, w_0} .$$


- ⊕ Отбор признаков с параметром *селективности*  $\mu$ :  
чем больше  $\mu$ , тем меньше признаков останется
- ⊕ Есть эффект группировки
- ⊖ Шумовые признаки также группируются вместе,  
и группы значимых признаков могут отбрасываться,  
когда ещё не все шумовые отброшены

---

*Li Wang, Ji Zhu, Hui Zou.* The doubly regularized support vector machine // *Statistica Sinica*, 2006. No 16, Pp. 589–615.

## Support Features Machine (SFM)

$$C \sum_{i=1}^{\ell} (1 - M_i(w, w_0))_+ + \sum_{j=1}^n R_{\mu}(w_j) \rightarrow \min_{w, w_0} .$$
$$R_{\mu}(w_j) = \begin{cases} 2\mu|w_j|, & |w_j| \leq \mu; \\ \mu^2 + w_j^2, & |w_j| \geq \mu; \end{cases}$$



- ⊕ Отбор признаков с параметром селективности  $\mu$
- ⊕ Есть эффект группировки
- ⊕ Значимые зависимые признаки ( $|w_j| > \mu$ ) группируются и входят в решение совместно (как в Elastic Net),
- ⊕ Шумовые признаки ( $|w_j| < \mu$ ) подавляются независимо (как в LASSO)

---

*Tatarchuk A., Urlov E., Mottl V., Windridge D. A support kernel machine for supervised selective combining of diverse pattern-recognition modalities // Multiple Classifier Systems. LNCS, Springer-Verlag, 2010. Pp.165–174.*

## Relevance Features Machine (RFM)

$$C \sum_{i=1}^{\ell} (1 - M_i(w, w_0))_+ + \sum_{j=1}^n \ln(w_j^2 + \frac{1}{\mu}) \rightarrow \min_{w, w_0} .$$

- ⊕ Отбор признаков с параметром *селективности*  $\mu$ :  
чем больше  $\mu$ , тем меньше признаков останется
- ⊕ Есть эффект группировки
- ⊕ Лучше отбирает набор значимых признаков, когда  
они лишь совместно обеспечивают хорошее решение

---

*Tatarchuk A., Mottl V., Eliseyev A., Windridge D.* Selectivity supervision in combining pattern recognition modalities by feature- and kernel-selective Support Vector Machines // 19th International Conference on Pattern Recognition, Vol 1-6, 2008, Pp. 2336–2339.

## Регуляризация нестационарной регрессии

Линейная модель регрессии:

$$a(x_t, w_t) = \langle x_t, w_t \rangle = \sum_{j=1}^n x_{tj} w_{tj}, \quad x_t, w_t \in \mathbb{R}^n$$

где параметр модели  $w_t \in \mathbb{R}^n$  зависит от времени  $t$ .

Метод наименьших квадратов:

$$Q(w, X^T) = \sum_{t=1}^T (a(x_t, w_t) - y_t)^2 \rightarrow \min_{\{w_{jt}\}}$$

Регуляризация:


$$Q(w, X^T) + \mu \sum_{t=1}^T \sum_{j=1}^n w_{tj}^2 + \eta \sum_{t=1}^{T-1} \sum_{j=1}^n |w_{t+1,j} - w_{tj}| \rightarrow \min_{\{w_{jt}\}}$$

$\mu$  — параметр селективности;

$\eta$  — параметр изменчивости коэффициентов во времени;

## Пример. Оценивание динамики портфеля хедж-фонда

«Чёрная среда», 16-09-1992, фонд Quantum (Дж.Сорос):  
обнаружен момент реструктуризации портфеля (продажа GBP)



Created with open Office

*O. Krasotkina, A. Kopylov, V. Mottl, M. Markov. Bayesian estimation of time-varying regression with changing time-volatility for detection of hidden events in nonstationary signals // SPPRA, 2010.*

## Процедура порождения и выбора моделей

- Задаётся множество достаточно простых параметрических порождающих функций
- Метаэвристиками порождается множество суперпозиций
- Настраиваются параметры модели  $w$ ;  
байесовский вывод приводит к регуляризатору  $w^T A w$ ,  
где  $A^{-1}$  — ковариационная матрица.
- Выбирается модель с наименьшей длиной описания.



**Реализация с открытым кодом:**

MVR Composer, <http://strijov.com>

---

*Стрижов В. В.* Порождение и выбор моделей в задачах регрессии и классификации. Диссертация на соискание ученой степени д.ф.-м.н., ВЦ РАН, 2014.

## Модель давления в камере сгорания дизельного двигателя



Давление в камере сгорания дизельного двигателя:


$x$  — угол поворота коленчатого вала (нормализованный),

$y$  — давление (нормализованное), выборка включает 4000 элементов.

---

Стрижов В.В. Методы выбора регрессионных моделей. М.: ВЦ РАН, 2010.

## Порожденные и выбранные модели давления



Обозначения:  $h$  — гауссова функция  $y = \lambda \frac{1}{\sqrt{2\pi}\sigma} \exp(-\frac{1}{2\sigma^2}(x - \xi)^2 + a)$ ,  
 $c$  — кубическая  $y = ax^3 + bx^2 + cx + d$ ,  $|$  — линейная  $y = ax + b$ .

$$y = (ax + b)^{-1} \left( x + \sum_{i=1}^3 \frac{\lambda_i}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{(x - \xi_i)^2}{2\sigma_i^2}\right) + a_i \right).$$



Рудой Г.И., Стрижов В.В. Алгоритмы индуктивного порождения суперпозиций для аппроксимации измеряемых данных // Информатика и её применения, 2013, 7(1): 17-26.

## Модель волатильности опционов

Модель волатильности европейского опциона на сырую нефть.

Волатильность  $\sigma$  зависит от времени  $t$  и цены исполнения  $K$ :

$$\sigma = \frac{1}{\sqrt{t}}(w_1 K + w_2)(w_1 K^2 + w_2 K + w_3)^2.$$



Сологуб Р. А. Алгоритмы индуктивного порождения и трансформации моделей в задачах нелинейной регрессии. Диссертация к.ф.-м.н. ВЦ РАН, 2014.

## Задачи матричного разложения

Дано: матрица  $Z = \|z_{ij}\|_{n \times m}$ .

Найти: матрицы  $X = \|x_{it}\|_{n \times k}$  и  $Y = \|y_{tj}\|_{k \times m}$  такие, что

$$\|Z - XY\|_D = \sum_{i=1}^n \sum_{j=1}^m D\left(z_{ij}, \sum_t x_{it} y_{tj}\right) \rightarrow \min_{X, Y}$$

Типы задач:

- различные нормы  $D$ : Фробениуса, KL-дивергенция, ...
- неотрицательные матричные разложения:  $x_{it} \geq 0$ ,  $y_{tj} \geq 0$
- стохастические матричные разложения:  $\sum_i x_{it} = 1$ ,  $\sum_t y_{tj} = 1$
- разреженные данные: известны только  $z_{ij}$ ,  $(i, j) \in \Omega$ :

$$\sum_{(i,j) \in \Omega} D\left(z_{ij}, \sum_t x_{it} y_{tj}\right) \rightarrow \min_{X, Y}$$

## Примеры прикладных задач матричного разложения

### 1 Анализ данных жидкостной хроматографии

$$z(t, \lambda) = \sum_i X_i(t) Y_i(\lambda)$$

**дано:**  $z(t, \lambda)$  — выход сканирующего УФ-детектора;

**найти:**  $X_i(t)$  — хроматограмма  $i$ -го вещества,  $t$  — время

$Y_i(\lambda)$  — спектр  $i$ -го вещества,  $\lambda$  — длина волны.

### 2 Анализ данных ДНК-микрочипов

$$I(p, k) = \sum_g a_{pg} C_{gk}$$

**дано:**  $I(p, k)$  — интенсивность свечения  $p$ -й пробы на  $k$ -м чипе;

**найти:**  $a_{pg}$  — коэффициент сродства  $p$ -й пробы  $g$ -му гену,

$C_{gk}$  — концентрация  $g$ -го гена на  $k$ -м чипе.

## Примеры прикладных задач матричного разложения

### 3 Рекомендательные системы

$$R_{iu} = \sum_t p_i(t)q_u(t)$$

**дано:**  $R_{iu}$  — рейтинги товаров  $i$ , поставленные пользователем  $u$ ;

**найти:**  $p_i(t)$  — профиль интересов товара  $i$ ;

$q_u(t)$  — профиль интересов пользователя  $u$ .

### 4 Тематическое моделирование текстовых коллекций

$$p(w|d) = \sum_t p(w|t)p(t|d)$$

**дано:**  $p(w|d) = \frac{n_{dw}}{n_d}$  — частоты слов  $w$  в документах  $d$ ;

**найти:**  $\phi_{wt} = p(w|t)$  — распределения слов  $w$  в темах  $t$ ,

$\theta_{td} = p(t|d)$  — распределения тем  $t$  в документах  $d$ .

## PLSA — Probabilistic Latent Semantic Analysis [Hofmann, 1999]

Задача максимизации логарифма правдоподобия:

$$\sum_{d,w} n_{dw} \ln \sum_t \phi_{wt} \theta_{td} \rightarrow \max_{\Phi, \Theta}$$

EM-алгоритм: метод простой итерации для системы уравнений со вспомогательными переменными  $p_{tdw} = p(t|d, w)$ :

$$\begin{array}{l} \text{E-шаг:} \\ \text{M-шаг:} \end{array} \left\{ \begin{array}{l} p_{tdw} = \mathop{\text{norm}}_{t \in T} (\phi_{wt} \theta_{td}) \\ \phi_{wt} = \mathop{\text{norm}}_{w \in W} \left( \sum_{d \in D} n_{dw} p_{tdw} \right) \\ \theta_{td} = \mathop{\text{norm}}_{t \in T} \left( \sum_{w \in W} n_{dw} p_{tdw} \right) \end{array} \right.$$

где  $\mathop{\text{norm}}_{t \in T} x_t = \frac{\max\{x_t, 0\}}{\sum_{s \in T} \max\{x_s, 0\}}$  — операция нормировки вектора.

## ARTM — Аддитивная регуляризация тематических моделей

Максимизация  $\log$  правдоподобия с регуляризатором  $R$ :

$$\sum_{d,w} n_{dw} \ln \sum_t \phi_{wt} \theta_{td} + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}$$

EM-алгоритм: метод простой итерации для системы уравнений

$$\begin{cases} \text{E-шаг:} & p_{tdw} = \mathop{\text{norm}}_{t \in T}(\phi_{wt} \theta_{td}) \\ \text{M-шаг:} & \begin{cases} \phi_{wt} = \mathop{\text{norm}}_{w \in W} \left( \sum_{d \in D} n_{dw} p_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right) \\ \theta_{td} = \mathop{\text{norm}}_{t \in T} \left( \sum_{w \in D} n_{dw} p_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right) \end{cases} \end{cases}$$

Воронцов К. В. Аддитивная регуляризация тематических моделей коллекций текстовых документов. Доклады РАН, 2014. Т. 455., № 3. 268–271.

## Комбинирование регуляризованных тематических моделей

Максимизация  $\log$  правдоподобия с  $n$  регуляризаторами  $R_i$ :

$$\sum_{d,w} n_{dw} \ln \sum_t \phi_{wt} \theta_{td} + \sum_{i=1}^n \tau_i R_i(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta},$$

где  $\tau_i$  — коэффициенты регуляризации.

EM-алгоритм: метод простой итерации для системы уравнений

$$\begin{cases} \text{E-шаг:} & p_{tdw} = \mathop{\text{norm}}_{t \in T}(\phi_{wt} \theta_{td}) \\ \text{M-шаг:} & \begin{cases} \phi_{wt} = \mathop{\text{norm}}_{w \in W} \left( \sum_{d \in D} n_{dw} p_{tdw} + \phi_{wt} \sum_{i=1}^n \tau_i \frac{\partial R_i}{\partial \phi_{wt}} \right) \\ \theta_{td} = \mathop{\text{norm}}_{t \in T} \left( \sum_{w \in W} n_{dw} p_{tdw} + \theta_{td} \sum_{i=1}^n \tau_i \frac{\partial R_i}{\partial \theta_{td}} \right) \end{cases} \end{cases}$$

## Мультимодальная ARTM [Vorontsov et al, 2015]

$W^m$  — словарь токенов  $m$ -й модальности,  $m \in M$

$W = W^1 \sqcup \dots \sqcup W^M$  — объединённый словарь всех модальностей

Максимизация суммы  $\log$  правдоподобий с регуляризацией:

$$\sum_{m \in M} \lambda_m \sum_{d \in D} \sum_{w \in W^m} n_{dw} \ln \sum_t \phi_{wt} \theta_{td} + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}$$

EM-алгоритм: метод простой итерации для системы уравнений

$$\begin{array}{l} \text{E-шаг:} \\ \text{M-шаг:} \end{array} \left\{ \begin{array}{l} p_{tdw} = \mathop{\text{norm}}_{t \in T} (\phi_{wt} \theta_{td}) \\ \phi_{wt} = \mathop{\text{norm}}_{w \in W^m} \left( \sum_{d \in D} \lambda_{m(w)} n_{dw} p_{tdw} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right) \\ \theta_{td} = \mathop{\text{norm}}_{t \in T} \left( \sum_{w \in d} \lambda_{m(w)} n_{dw} p_{tdw} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right) \end{array} \right.$$

## BigARTM: библиотека тематического моделирования

### Ключевые возможности:

- **Онлайновая параллельная** мультимодальная ARTM
- Большие данные: коллекция не хранится в памяти
- Встроенная библиотека регуляризаторов

### Сообщество:

- Открытый код <https://github.com/bigartm>  
(discussion group, issue tracker, pull requests)
- Документация <http://bigartm.org>



### Лицензия и среда разработки:

- Freely available for commercial usage (BSD 3-Clause license)
- Cross-platform — Windows, Linux, Mac OS X (32 bit, 64 bit)
- Programming APIs: command-line, C++, and Python

## Эксперимент 1. Обгоняем конкурентов по скорости

- 3.7M статей английской Вики, 100K уникальных слов


	procs	train	inference	perplexity
BigARTM	1	35 min	72 sec	4000
Gensim.LdaModel	1	369 min	395 sec	4161
VowpalWabbit.LDA	1	73 min	120 sec	4108
BigARTM	4	9 min	20 sec	4061
Gensim.LdaMulticore	4	60 min	222 sec	4111
BigARTM	8	4.5 min	14 sec	4304
Gensim.LdaMulticore	8	57 min	224 sec	4455

- *procs* = число параллельных потоков
- *inference* = время тематизации 100K тестовых документов
- *perplexity* вычислена на тестовой выборке документов

## Эксперимент 2. Масштабируемость по числу потоков

коллекция	$ W , 10^3$	$ D , 10^6$	$n, 10^6$	размер, Гб
enron	28	0.04	6.4	0.07
nytimes	103	0.3	100	0.13
pubmed	141	8.2	738	1.0
wiki	100	3.7	1009	1.2

ускорение



Amazon EC2 cc2.8xlarge instance:

16 cores + hyperthreading, Intel<sup>®</sup> Xeon<sup>®</sup> CPU E5-2670 2.6GHz.

## Эксперимент 3. Выявление этнических тем в социальной сети

- Выделение этно-релевантных тем
  - регуляризатор частичного обучения по словарю этнонимов
  - альтернативный вариант: этнонимы как модальность
  - регуляризаторы для контрастирования малых тем
- Повышение качества тематической модели
  - использование модальности авторов
  - выявление тематических сообществ
  - лингвистическая регуляризация и выделение мультиграмм
- Оценивание распределения тем по регионам
  - разреживание региональных тем
  - сглаживание общих тем
- Оценивание распределения тем по времени
  - разреживание событийных тем
  - сглаживание перманентных тем

## Примеры этнических тем

**(русские)**: русский, князь, россия, татарин, великий, царить, царь, иван, император, империя, грозить, государь, век, московская, екатерина, москва,

**(русские)**: акция, организация, митинг, движение, активный, мероприятие, совет, русский, участник, москва, оппозиция, россия, пикет, протест, проведение, националист, поддержка, общественный, проводить, участие,

**(славяне, византийцы)**: славянский, святослав, жрец, древние, письменность, рюрик, летопись, византия, мефодий, хазарский, русский, азбука,

**(сирийцы)**: сирийский, асад, боевик, район, террорист, уничтожить, группировка, дамаск, оружие, алесии, оппозиция, операция, селение, сша, нусра, турция,

**(турки)**: турция, турецкий, курдский, эрдоган, стамбул, страна, кавказ, горин, полиция, премьер-министр, регион, курдистан, ататюрк, партия,

**(иранцы)**: иран, иранский, сша, россия, ядерный, президент, тегеран, сирия, оон, израиль, переговоры, обама, санкция, исламский,

**(палестинцы)**: террорист, израиль, терять, палестинский, палестинец, террористический, палестина, взрыв, территория, страна, государство, безопасность, арабский, организация, иерусалим, военный, полиция, газ,

**(ливанцы)**: ливанский, боевик, район, ливан, армия, террорист, али, военный, хизбалла, раненый, уничтожить, сирия, подразделение, квартал, армейский,

**(либийцы)**: ливан, демократия, страна, ливийский, каддафи, государство, алжир, война, правительство, сша, арабский, али, муаммар, сирия,

## Примеры этнических тем

**(евреи)**: израиль, израильский, страна, война, нетаньяху, тель-авив, время, сша, сирия, египет, случай, самолет, еврейский, военный, ближний,

**(американцы)**: американский, американка, война, россия, военный, страна, вашингтон, америка, армия, конгресс, сирия, союзный, российский, обама, войска, русский, оружие, операция,

**(немцы)**: армия, война, войска, советский, военный, дивизия, немец, фронт, немецкий, генерал, борт, операция, оборона, русский, бог, победа,

**(немцы)**: германий, немец, германский, ссср, немецкий, война, старое, советский, россия, береза, русский, правительство, территория, полный, документ, вопрос, сорт, договор, отношение, франция,

**(евреи, немцы)**: еврей, еврейский, холодный, германий, антисемитизм, гетра, немец, синагога, сша, израиль, малиновского, комиссия, нацбол, документ, война, еврейка, миллион, украина,

**(украинцы, немцы)**: украинский, унс, оун, немец, немецкий, ковальков, хохол, волинский, бандера, организация, россиянин, советский, русский, польский, армия, шухевича, ровенский,

**(таджики, узбеки)**: мигрант, страна, россия, миграция, азия, нелегальный, миграционный, таджикистан, гастарбайтер, гражданка, трудовой, рабочий, фмс, коренево, среднее, узбекистан, таджик, проблема, русский, население,

**(канадцы)**: команда, игра, игрок, канадский, сезон, хоккей, сборная, играть, болельщик, победа, кубок, счет, забирать, хоккейный, выигрывать, хоккеист, чемпионат, шайба,

## Примеры этнических тем

**(японцы)**: японский, япония, корея, китайский, жилища, авария, фукусиму, цунами, сообщать, океан, станция, хатико, район, правительство, атомный,

**(норвежцы)**: дитя, ребенок, родиться, детский, семья, воспитанный, право, возраст, отец, воспитание, норвежский, родительский, родить, мальчик, взрослый, опека, сын,

**(венесуэльцы)**: куба, кастро, венесуэла, чавес, президент, уго, мадура, боливия, фидель, глава, латинский, венесуэльский, лидер, боливарианской, президентский, альенде, гевару,

**(китайцы)**: китайский, россия, производство, китаи, продукция, страна, предприятие, компания, технология, военный, регион, производить, производственный, промышленность, российский, экономический, кнр,

**(азербайджанцы)**: русский, азербайджан, азербайджанец, россия, азербайджанский, таксист, диаспора, анапа, народ, москва, страна, армянин, слово, рынок,

**(грузины)**: грузинский, спецназ, военный, август, баташева, российский, спецназовец, миротворец, операция, румын, бригада, миротворческий, абхазия, группа, войска, русский, цхинвале,

**(осетины)**: конституция, осетия, аминат, русский, осетинский, южный, северный, россия, война, республика, вопрос, алахай, российский, население, конфликт,

**(цыгане)**: наркотик, цыган, цыганка, хороший, место, страна, деньга, время, работать, жизнь, жить, рука, дом, цыганский, наркоманка,

## Несколько тезисов в заключение

- Регуляризации — инструмент решения некорректно поставленных задач восстановления зависимостей
- Big Data — субквадратичные алгоритмы
- Predictive Analytics — предсказательные модели
- Deep Learning — глубокие суперпозиции моделей
- Data Science — профессия будущего: число прикладных задач растёт во всех областях науки и бизнеса
- «Система Физтеха»: Физтех — база ВЦ РАН — компании

Воронцов Константин Вячеславович

[voron@forecsys.ru](mailto:voron@forecsys.ru)

[www.MachineLearning.ru/wiki?title=User:Vokov](http://www.MachineLearning.ru/wiki?title=User:Vokov)